

# 基于去噪卷积神经网络的雷达信号调制类型识别

肖易寒<sup>\*①</sup> 王亮<sup>①</sup> 郭玉霞<sup>②③</sup>

<sup>①</sup>(哈尔滨工程大学信息与通信工程学院先进船舶通信与信息技术工业和信息化部重点实验室 哈尔滨 150000)

<sup>②</sup>(中国空空导弹研究院 洛阳 471009)

<sup>③</sup>(航空制导武器航空科技重点实验室 洛阳 471009)

**摘要:** 针对低截获概率雷达(LPI)信号处理复杂,低信噪比条件下识别率低的问题,该文提出一种基于去噪卷积神经网络和Inception网络的信号分类识别系统。首先对8种LPI雷达信号进行Choi-Williams分布(CWD)时频变换,得到2维时频图像,然后使用去噪卷积神经网络进行时频图像去噪处理,最后将图像发送到Inception-V4网络进行特征提取,并使用softmax分类器进行分类,实现LPI雷达信号的有效分类识别。仿真结果表明,该方法在-10 dB信噪比(SNR)下,识别率仍然可以达到90%以上。

**关键词:** 低截获概率雷达信号; Choi-Williams分布时频变换; 去噪卷积神经网络; Inception-V4网络

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2021)08-2300-08

DOI: 10.11999/JEIT200506

## Radar Signal Modulation Type Recognition Based on Denoising Convolutional Neural Network

XIAO Yihan<sup>①</sup> WANG Liang<sup>①</sup> GUO Yuxia<sup>②③</sup>

<sup>①</sup>(Key Laboratory of Advanced Marine Communication and Information Technology, Ministry of Industry and Information Technology, Harbin Engineering University, Harbin 150000, China)

<sup>②</sup>(China Airborne Missile Academy, Luoyang 471009, China)

<sup>③</sup>(Aviation Key Laboratory of Science and Technology on Airborne Guided Weapons, Luoyang 471009, China)

**Abstract:** Considering the problems of Low Probability of Intercept (LPI) radar signal processing complexity and low recognition rate under the condition of low SNR, a signal classification and recognition system based on Denoising Convolution Neural Network (DnCNN) and Inception network is proposed. Firstly, eight kinds of LPI radar signals are transformed by Choi Williams Distribution (CWD) to obtain two-dimensional time-frequency images. Then, the denoising convolution neural network is used to denoise the time-frequency images. Finally, the images are sent to the Inception-v4 network for feature extraction, and the softmax classifier is used for classification to realize the effective classification and recognition of LPI radar signals. Simulation results show that the recognition rate of this method can still reach more than 90% under -10 dB Signal-Noise Ratio (SNR).

**Key words:** Low Probability of Intercept (LPI) radar signal; Choi-Williams Distribution (CWD) time-frequency transform; Denoising Convolutional Neural Network (DnCNN); Inception-V4 network

### 1 引言

低截获概率雷达由于拥有低功率、大带宽等优点,并且自身可以发射各种复杂的调制信号,使得

非合作接收机难以对其进行分析。因此,针对低截获概率(Low Probability of Intercept, LPI)雷达发射信号进行有效的特征提取与识别成为关键。

由于数字信号处理技术的发展,对于脉内特征参数的雷达信号识别发展迅速。文献[1]利用调制宽带转换器(Modulated Wideband Converter, MWC)离散压缩采样的新型宽带数字接收机结构,提出基于短时傅里叶变换以及频谱能量聚焦率检验的识别算法,对6种调制类型信号(NS, BPSK, QPSK, LFM, NLFM, 2FSK)进行分类识别,在信噪比为4 dB时识别率可以达到90%。然而这种方法需要人

收稿日期: 2020-06-19; 改回日期: 2021-04-10; 网络出版: 2021-05-06

\*通信作者: 肖易寒 xiaoyihan@hrbeu.edu.cn

基金项目: 国家自然科学基金(61571146), 中央高校基本科研基金(3072020CF0810), 航空科学基金(201801P6004)

Foundation Items: The National Natural Science Foundation of China (61571146), The Basic Scientific Research business Fees of the Central University (3072020CF0810), The Aviation Science Foundation (201801P6004)

为提取特征, 所以极其依赖特征参数的设计。随着卷积神经网络在图像处理与识别方面的大量应用<sup>[2]</sup>, 将深度学方法应用于LPI雷达时频图像(Time-Frequency Image, TFI)处理与识别的方法越来越多。文献<sup>[3]</sup>提出利用Choi-Williams分布(Choi Williams Distribution, CWD)进行时频分析, 采用LeNet-5结构识别多种调制类型信号, 在信噪比为-2 dB时, BPSK, LFM, Costas码、Frank码和多时码(T1, T2, T3和T4)的8种信号的识别率达到93.7%。在此基础上, 文献<sup>[4]</sup>在对TFI进行特征提取与识别时使用AlexNet模型结构, 加深和优化了网络结构, 对CW, LFM, EQFM, DLFM, BFSK, BPSK以及QPSK这7种雷达信号进行特征的自动提取和选择, 并且在信噪比为-6 dB时识别率达到90%以上。然而上述方法存在CNN网络中的梯度弥散等问题, 因此无法确保网络训练时的稳定性。文献<sup>[5]</sup>采用的残差网络基本解决了这一问题, 但是对于时频图像的预处理不够, 导致低信噪比下的识别效果仍然有限。文献<sup>[6]</sup>使用栈式稀疏自编码器对8种LPI雷达波形进行识别。在对信号时频图像进行有效预处理的同时, 也在一定程度上缓解传统CNN网络中存在的问题, 然而预处理过程复杂, 因此仍然有其局限性。

在改进网络模型时, 同样也提出了迁移学习的思想, 文献<sup>[7]</sup>将迁移学习应用于Inception-V3和ResNet-152网络进行特征提取, 使用SVM作为分类器, 在信噪比为-2 dB时, 8种LPI雷达信号(LFM, BPSK, Costas, Frank和T1~T4)的总识别率达到97.8%, 同时文献<sup>[8]</sup>也将迁移学习以及特征融合思想结合, 并使用VGG网络进行特征提取与识别, 同样达到相似的识别效果。然而迁移学习仅适用参数小范围波动的数据, 并且由于特征提取时采用共享参数思想, 因此其普适性较差。上述文献不断对网络结构进行改进, 而在时频图像的预处理方面工作较少, 因此需要对图像进行有效的预处理。文献<sup>[9]</sup>通过图像滤波、图像开放操作、骨架提取、主成分分析(PCA)、图像二值化算法和伪Zernike矩等技术, 从接收数据的CWD图像中提取特征。并使用Elman神经网络(Elman Neural Network, ENN)分类器, 对8种调制信号进行了分类, 在信噪比为-2 dB时, 识别成功率为94.7%。文献<sup>[10]</sup>则应用2维维纳滤波、双线性插值和OTSU方法等一系列图像处理技术, 去除了TFI的背景噪声, 获得了仅包含TFI形态特征的固定尺寸二值图像, 并且使用CNN进行分类。然而这些方法预处理过程烦琐、复杂, 实时性差。因此, 如何对雷达信号时

频图像进行有效的预处理, 并且尽可能多保留雷达波形特征信息, 提高在低信噪比条件下识别率, 是LPI雷达信号识别的一个具有挑战性的问题。

目前, CNN网络在雷达信号识别中已经取得良好的效果, 然而由于传统CNN网络中存在许多问题, 而且对于如何提高低信噪比下的雷达波形识别工作还尚显不足。文献<sup>[11]</sup>将残差去噪网络应用于通信信号处理中, 证明了残差去噪网络的有效性, 因此本文针对低信噪比下的雷达调制信号识别进行研究, 提出采用基于残差思想的去噪卷积神经网络算法对多种调制类型信号时频图像进行去噪预处理, 并且使用Inception-V4网络进行去噪后的时频图像的特征提取, 最后使用softmax分类器进行雷达波形分类。

## 2 有意调制信号分析

雷达信号是一种非平稳信号, 传统的时域和频域分析方法只能获得非常有限的信号信息。时频分析是处理非平稳信号的有力工具, 有助于分析雷达信号特性, 它将1维时间信号映射到2维时频平面上, 充分刻画了非平稳信号的时频联合特性。时频分析不仅反映了信号能量在时间和频率上的分布, 而且揭示了频率与时间的关系。

已有两种时频分析方法包括线性表示法和非线性表示法。本文主要研究非线性时频分布, 典型的非线性时频分析包括Wigner-Ville分布(WVD)、Choi-Williams分布(CWD)等<sup>[12, 13]</sup>。CWD时频分析于1989年提出, 它在所有未经处理的类Cohen分布中都表现出最小的交叉干扰, 并且对于不同时间或频率的信号具有较高的分辨率和识别精度

$$C_f(t, \omega, \phi) = \frac{1}{2\pi} \iiint e^{j(\xi\mu - \tau\omega - \xi t, \tau)} \cdot \phi(\xi, \tau) A(\mu, \tau) d\mu d\tau d\xi \quad (1)$$

$A(\mu, \tau)$ 为时间信号的模糊函数

$$A(\mu, \tau) = x\left(\mu + \frac{\tau}{2}\right) x^*\left(\mu - \frac{\tau}{2}\right) \quad (2)$$

其中,  $x(\mu)$ 为时间信号;  $x^*(\mu)$ 为其共轭。 $\phi(\xi, \tau)$ 为核函数, 核函数不同, 时频分布不同, 当核函数为指数加权形式时, 即为CWD时频分布

$$\phi(\xi, \tau) = e^{-\xi^2 \tau^2 / \sigma} \quad (3)$$

其中,  $\sigma(\sigma > 0)$ 是缩放因子, 式(3)在减少交叉项方面具有一定作用。

本文使用离散形式的CWD函数

$$C_x(l, \omega) = 2 \sum_{\tau=-\infty}^{+\infty} e^{-j2\omega\tau} \sum_{\mu=-\infty}^{+\infty} e^{-\sigma(\mu-l)/4\tau^2} \cdot x(\mu + \tau) x^*(\mu - \tau) \quad (4)$$

对8种低截获概率雷达信号进行CWD时频变换,得到时频图像,包括BPSK, Frank, T1~T4, LFM以及Costas信号。如图1所示,其中, Barker码调制方式为BPSK调制, Costas代码数目设置为5, T1~T4代码每段频率步数的采样数设置为8。

由于减少了交叉项干扰, 8种信号的CWD时频图像准确地展示了信号调制周期与带宽, 同时反映了信号调制的固有属性, 为后续特征提取以及波形检测提供了新的思路与方法。

### 3 基于残差网络的雷达信号时频图像去噪算法

传统卷积神经网络进行去噪时, 由于存在过拟合, 梯度爆炸或者梯度消失等问题, 使得网络层数较浅, 当使用正则化项时, 虽然可以使网络收敛, 但精度却趋于饱和, 而单纯的增加网络层数无法解决这一类问题。因此文献[14]提出基于残差学习和批规范处理的卷积神经网络去噪算法, 残差网络采用跳跃连接方式, 通过输入与残差的和作为网络输出。残差网络结构使得网络层数大大增加, 且网络便于训练, 收敛速度快。在此基础上, 去噪卷积神经网络(Denoising Convolutional Neural Network, DnCNN)算法保留残差网络优点, 去除小残差块, 仅采用一个残差结构进行学习, 同时加入批规范化(Batch Normalization, BN), 可以提高网络训练速度, 提高去噪性能<sup>[15]</sup>。

在雷达信号中, 信号噪声模型一般为加性高斯白噪声, 因此, 在将原始雷达信号并添加噪声后再进行时频变换时, 其噪声模型也同样体现在时频图像上。与直接在图像上添加噪声的方式不同, 本文要去除的噪声模型为时域上添加的噪声经过CWD

变换而来, 式(5)—式(7)展示了本文对于时频图像的处理方式。首先对添加噪声的时域信号进行时频变换, 然后对未添加噪声的时域信号进行时频变换, 而二者差值即为图像的背景噪声

$$Y = C_x(s(t) + n(t)) \quad (5)$$

$$X = C_x(s(t)) \quad (6)$$

$$V = Y - X \quad (7)$$

其中,  $C_x$ 表示CWD时频变换,  $s(t)$ 为未添加噪声的时域信号,  $n(t)$ 为高斯噪声,  $Y$ 为添加噪声的时域信号的时频图像,  $X$ 为无噪声时域信号的时频图像,  $V$ 为二者差值, 即为去除原始信号, 仅剩噪声的时频图像。由式(7)展示的噪声模型, 很多网络通过学习映射函数 $F(y) = x$ 从而预测无噪声的干净图像, 而对于残差网络, 是基于 $R(y) \approx v$ 的函数映射学习图像噪声残差进而实现图像去噪的, 将其代入式(7)中得到 $x = y - R(y)$ , 最终通过用期望的噪声残差值和通过卷积网络计算得到的估计噪声的残差值求得均方误差。

如图2所示是基于去噪卷积神经网络的时频图像去噪算法。设添加噪声的雷达信号通过CWD变换后的灰度图像为 $y$ , 与其对应的未添加噪声的图像为 $x$ , 上述二者差值即为目标残差图像 $\hat{M} = (y - x)$ ,  $y$ 经过 $L$ 层CNN网络后的输出为真实残差图像 $M(y; \theta)$ , 对于每对残差图像 $(M, \hat{M})$ , 利用平均均方误差(Mean Square Error, MSE)构建代价函数

$$D(\theta) = \frac{1}{N} \sum_{i=1}^N \left\| M_i - \hat{M}_i \right\|_F^2 \quad (8)$$

其中,  $N$ 为批规范化大小,  $\|\bullet\|_F$ 为F范数。

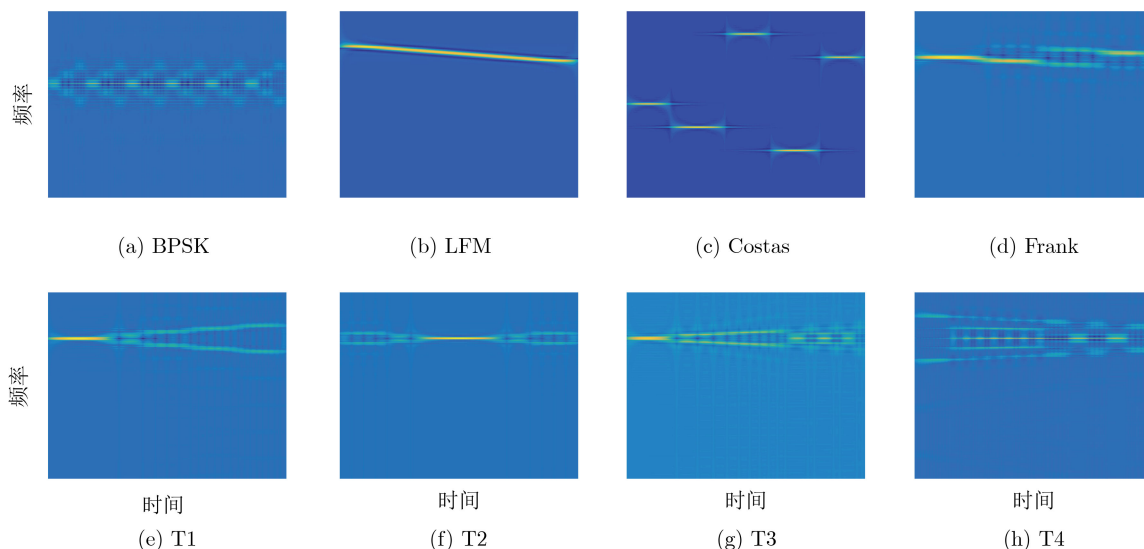


图1 不同调制方式LPI雷达信号时频图像

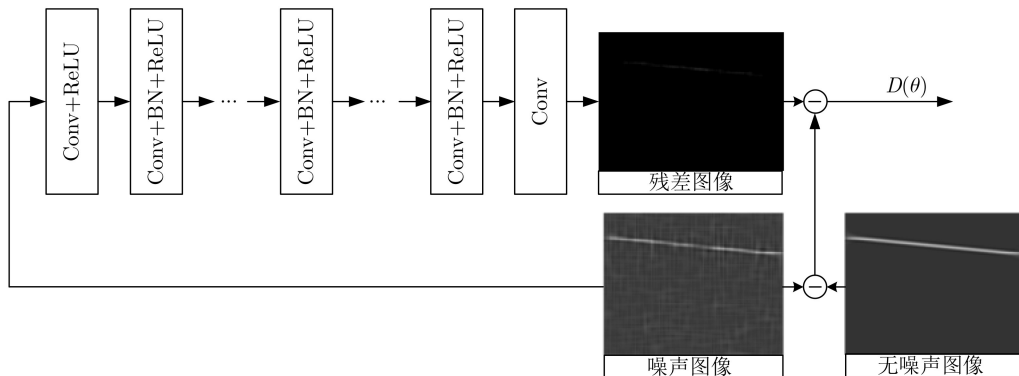


图 2 DnCNN去噪算法框图

网络通过最小化代价函数来不断学习网络参数  $\theta = (w_1, w_2, \dots, w_L, b_1, b_2, \dots, b_L)$ 。在网络训练完毕后进行去噪时，只需要将带噪声图像  $y$  输入网络，得到残差图像  $r$ ，最后将二者相减，即可得到去噪图像。

#### 4 基于Inception-V4网络的雷达信号识别模型

目前，深度学习模型因卷积神经网络能对数据进行深层次的特征提取，已经在图像识别领域取得巨大成功，因此可以将其应用于雷达信号识别领域。在GoogLeNet(Inception V1)的基础上，Inception-V2, V3, V4相继被提出<sup>[16]</sup>。本文所使用Inception-V4同样结合了残差网络(ResNet)，使用分支网络的思想。Inception网络的优点在于改变了网络的构造形式，使用Inception网络近似一个稀疏结构。这种架构采用Network in Network中的思想，使用Average Pooling代替全连接层，并学习VGG网络，将全部卷积核拆分成1维卷积(1×7, 7×1)和(1×3, 3×1)，使得网络深度增加，提高网络非线性<sup>[17]</sup>。

在将原始雷达信号进行时频变换，并且经过去

噪处理后的图像为灰度图，灰度图为2维图像，因此无法满足网络输入要求，需要对去噪后的灰度图进行预处理。如图3所示，首先使用双线性插值法将图片变为  $299 \times 299 \times 1$ ，继而采用步长为1的  $3 \times 3 \times 3$  卷积层将输入数据变为  $299 \times 299 \times 3$  维度数据，最后送入Inception-V4网络进行特征提取。经过Inception-V4网络输出为  $1 \times 1 \times 1536$ ，再经过softmax分类器输出为信号分类结果。

#### 5 实验结果与分析

##### 5.1 LPI雷达信号仿真参数设置

为了验证DnCNN网络的稳定性与有效性，对于每一种调制方式，均采用范围随机化参数，因此全部雷达数据参数均有不同。LPI雷达仿真参数设置具体情况如表1所示，其中采样率均设置为8 kHz， $U(\bullet)$ 为归一化频率。例如，初始频率为  $f_0 = 1000$  Hz，采样率为  $f_s = 8000$  Hz，则  $f_0 = U(f_0/f_s) = U(1/8)$ 。

##### 5.2 DnCNN去噪效果分析

针对每一种调制方式，均生成500张无噪声图片及其对应相同参数的添加-12~8 dB噪声的图片，其中400张用于训练，100张用于去噪结果测试。本次实验采用的是Tensorflow实现DnCNN，

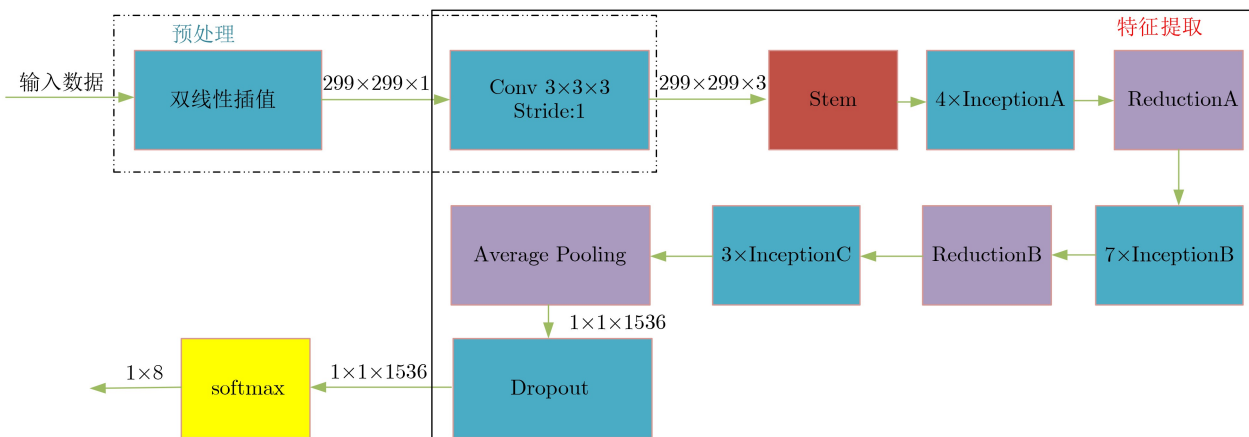


图 3 Inception-V4网络提取特征模型

表1 仿真参数

| 信号类型   | 信号参数            | 参数取值范围          |
|--------|-----------------|-----------------|
| LFM    | 信号长度 $N$        | [512, 1024]     |
|        | 带宽 $\Delta f$   | $U(1/16, 1/8)$  |
|        | 初始频率 $f_0$      | $U(1/16, 1/8)$  |
| Costas | 信号长度 $N$        | [512, 1024]     |
|        | 序列数量 $N_c$      | [3, 6]          |
|        | 基准频率 $f_{\min}$ | $U(1/24, 1/20)$ |
| Frank  | 载频 $f_c$        | $U(1/8, 1/4)$   |
|        | 循环相位码cpp        | [4, 6]          |
|        | 步进频率 $M$        | [4, 8]          |
| Barker | 巴克码长度 $N_c$     | {7, 11, 13}     |
|        | 载频 $f_c$        | $U(1/8, 1/4)$   |
|        | 码数量 $N_p$       | [100, 300]      |
|        | 循环相位码cpp        | [1, 5]          |
| T1~T4  | 信号长度 $N$        | [512, 1024]     |
|        | 整体码元周期 $T$      | [0.07, 0.1]     |
|        | 码序列段数 $k$       | [4, 6]          |

在训练网络时, 依次将每种调制方式类型的雷达信号时频图送入网络, 并保存模型, 构成模型库。在去噪时调用模型库中的模型进行去噪处理。

时域信号评价噪声方式为信号与噪声的有效功率的比值, 而评价图像噪声水平, 目前最常用的评价标准是结构相似性(SSIM)和峰值信噪比(PSNR)<sup>[18]</sup>。PSNR在图像去噪领域使用最多, 是一种全参考的评价指标, 它是一个关于峰值信号的能量与噪声信号的平均能量的一个比值, 这种方法是基于均方误差定义的。设两幅像素为 $m \times n$ 的图像 $A$ 与 $B$ , 其MSE定义以及PSNR定义为式(9)与式(10)

$$\text{MSE} = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n \|A(i, j) - B(i, j)\|^2 \quad (9)$$

$$\text{PSNR} = 20 \cdot \lg \left( \frac{\text{MAX}_I}{\sqrt{\text{MSE}}} \right) \quad (10)$$

其中,  $\text{MAX}_I$ 表示图像最大值, 这里使用范围为 $[0, 1]$ 的表示方式。


在训练结束后, 本次实验对少量数据进行测试, 信号添加噪声范围为 $-12 \sim 8$  dB, 间隔为2 dB, 每种信噪比情况使用100张图片进行测试。以Costas信号为例, 去噪后的灰度图如图4所示, 展示信噪比为 $-10$  dB雷达信号进行时频变换后再进行去噪后的灰度图, 并计算出去噪前时频图像的PSNR值为21.46 dB, 去噪后的时频图像的PSNR值为32.92 dB, 提高了11.46 dB。

由图中可以看出, CWD时频变换对低信噪比信号仍然可以保留大量特征信息, 但是时域信号的噪声也同样经过时频变换成为时频图像的背景噪声, 这导致时频图像的峰值信噪比不高, 而在经过DnCNN网络去噪后, 图像可以获得较高的峰值信噪比, 这为后续的Inception网络有效提取特征提供了有力的证据。表2展示了对于添加了不同噪声的不同调制类型的信号经过去噪后时频图的信噪比, 每种调制类型取100张图片去噪后的PSNR平均值。

由表中可以看出, 所有信号在使用残差去噪网络后时频图像峰值信噪均达到较高水平, 其中LFM信号去噪效果最优秀, 而BPSK信号去噪效果稍差。整体来看, 经过去噪后的时频图像峰值信噪比整体可以提升 $10 \sim 15$  dB, 良好的去噪能力对于低信噪比下的信号识别具有重要意义。

### 5.3 Inception-V4网络识别效果分析

为了验证DnCNN去噪网络在雷达时频图像中的有效性, 本文使用Inception-V4网络进行实验。本次实验数据分别使用去噪前的图像以及去噪后的图像用于网络的测试, 其中每种调制方式包含1200组数据, 80%用于训练, 20%用于测试, 信噪比范围为 $-12 \sim 8$  dB, 步长为2 dB, 其中Inception-V4网络使用交叉熵损失函数, 图5展示了信号在 $-10$  dB时采用DnCNN去噪网络的识别混淆矩阵以及未采用去噪网络的识别混淆矩阵。由图中可以看出, 使用DnCNN网络后再经过Inception-V4进行特征提取并分类的效果较好, 不过相似信号仍然



(a) 去噪前时频图像

(b) 去噪后时频图像

图4 DnCNN去噪灰度图

表 2 时频图去噪峰值信噪比(dB)

| 信号类型   | 雷达信号信噪比/视频图像峰值信噪比 |       |       |       |
|--------|-------------------|-------|-------|-------|
|        | -10               | -6    | -2    | 2     |
| LFM    | 34.02             | 34.56 | 35.67 | 37.12 |
| Costas | 32.15             | 33.31 | 34.55 | 35.01 |
| Frank  | 30.35             | 31.16 | 32.09 | 33.32 |
| BPSK   | 28.89             | 29.34 | 29.57 | 30.21 |
| T1     | 31.44             | 32.02 | 33.10 | 33.98 |
| T2     | 31.54             | 32.34 | 33.55 | 34.18 |
| T3     | 30.21             | 31.23 | 31.96 | 32.44 |
| T4     | 29.98             | 30.65 | 31.33 | 32.46 |

容易混淆，例如Frank与LFM，有较大的概率识别错误，但在低信噪比下整体识别率仍然可以达到90%以上。

为了验证本文方法的有效性，将与文献[3]提出的CNN模型以及文献[6]提出的栈式稀疏自编码(stacked Sparse Auto Encoder, sSAE)方法进行比较，一方面是本文使用信号调制方式与这两种方法完全相同，另一方面二者使用了不同的特征提取模型。其中，文献[6]所提出的栈式稀疏自编码器方法在LPI雷达波形识别中极具代表性，识别效果也同样优秀，因此具有很高的可比性。图6展示了这几种识别模型在不同信噪比下的不同调制方式的识别率。由图中可以看出，本文提出的DnCNN+Inception-V4方法整体上超越了文献[3]中方法的识别效果。而对于文献[6]而言，本文方法与之相比在不同调制类型信号识别的敏感度不同，在BPSK, Frank

等信号调制类型识别时本文方法一般高于sSAE方法，而在LFM信号的识别效果上则会弱于sSAE方法。同时不同的信噪比也会产生一定的影响，如T1和T2信号，在低信噪比下本文方法效果较好，但是在信噪比较高时识别效果反而上升缓慢，这是由于在高信噪比时信号的背景噪声逐渐减弱，DnCNN对于时频图像的去噪程度逐渐减弱导致的，但是最终的整体识别率本文方法是优于sSAE方法的。

### 5.4 鲁棒性分析

为了验证鲁棒性，采用不同批次的数据进行训练，图7展示的是每种调制方式的数据量不同情况下的识别率。图中表明，由于CWD时频变换对于信号时域特征的有效提取以及Inception网络对于时频图像特征提取的有效性，使得当样本量较小时，网络仍然可以收敛，在单种调制方式数据量为400时基本达到了稳定状态，从而获得较高的识别率，这证明了网络具有良好的鲁棒性。

## 6 结论

本文针对LPI雷达信号识别问题，提出基于去噪卷积神经网络和Inception-V4网络的LPI雷达信号分类识别系统。该系统采用CWD时频变换对信号进行时频域变换，使用DnCNN网络对时频图像进行预处理，在完整的保留时频图像信息的同时减小背景噪声，同时本文方法能够自动对图像提取特征，从而解决了人工提取特征复杂、效率低的问题，为低信噪比条件下的LPI雷达信号识别提供了新的方案。

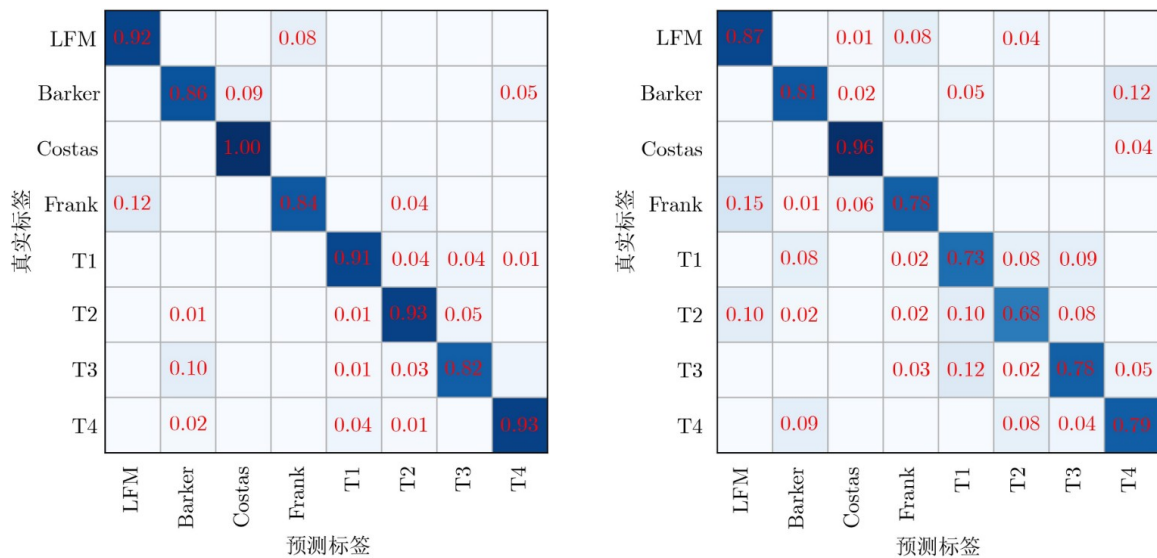


图 5 Inception-V4网络识别混淆矩阵

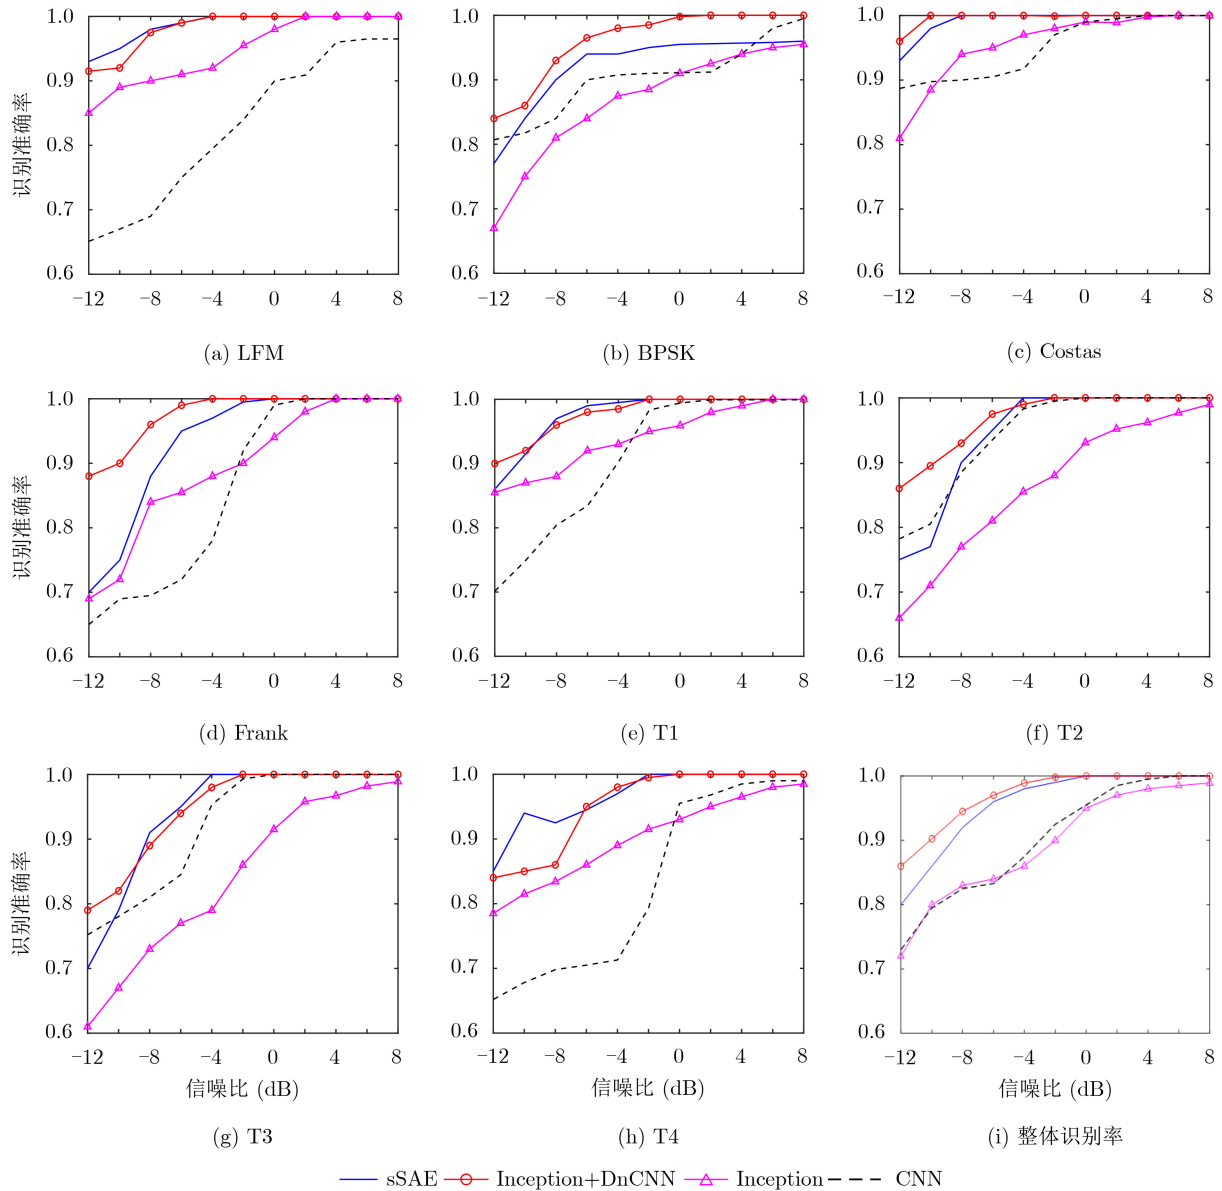


图6 不同信噪比下LPI雷达信号识别准确率

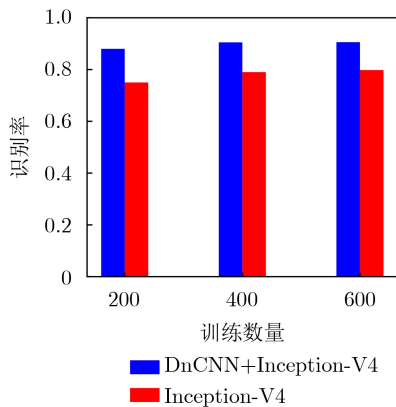


图7 不同数据量训练识别结果

参考文献

[1] 陈涛, 柳立志, 郭立民. 基于MWC压缩采样宽带接收机的雷达

信号脉内调制识别[J]. 电子与信息学报, 2018, 40(4): 867-874. doi: 10.11999/JEIT170612.

CHEN Tao, LIU Lizhi, and GUO Limin. Intra-pulse modulation recognition of radar signals based on MWC compressed sampling wideband receiver[J]. *Journal of Electronics & Information Technology*, 2018, 40(4): 867-874. doi: 10.11999/JEIT170612.

[2] TÜMEN V, SÖYLEMEZ Ö F, and ERGEN B. Facial emotion recognition on a dataset using convolutional neural network[C]. 2017 International Artificial Intelligence and Data Processing Symposium, Malatya, Turkey, 2017: 1-5. doi: 10.1109/IDAP.2017.8090281.

[3] ZHANG Ming, DIAO Ming, and GUO Limin. Convolutional neural networks for automatic cognitive radio waveform recognition[J] *IEEE Access*, 2017, 5: 11074-11082. doi:

- 10.1109/access.2017.2716191.
- [4] 郭立民, 陈鑫, 陈涛. 基于AlexNet模型的雷达信号调制类型识别[J]. 吉林大学学报: 工学版, 2019, 49(3): 1000–1008. doi: 10.13229/j.cnki.jdxbgxb20171056.  
GUO Limin, CHEN Xin, and CHEN Tao. Radar signal modulation type recognition based on AlexNet model[J]. *Journal of Jilin University: Engineering and Technology Edition*, 2019, 49(3): 1000–1008. doi: 10.13229/j.cnki.jdxbgxb20171056.
- [5] QIN Xin, ZHA Xiong, HUANG Jie, *et al.* Radar waveform recognition based on deep residual network[C]. The 8th IEEE Joint International Information Technology and Artificial Intelligence Conference, Chongqing, China, 2019: 892–896. doi: 10.1109/ITAIC.2019.8785588.
- [6] 郭立民, 寇韵涵, 陈涛, 等. 基于栈式稀疏自编码器的低信噪比下低截获概率雷达信号调制类型识别[J]. 电子与信息学报, 2018, 40(4): 875–881. doi: 10.11999/JEIT170588.  
GUO Limin, KOU Yunhan, CHEN Tao, *et al.* Low probability of intercept radar signal recognition based on stacked sparse Auto-encoder[J]. *Journal of Electronics & Information Technology*, 2018, 40(4): 875–881. doi: 10.11999/JEIT170588.
- [7] GUO Qiang, YU Xin, and RUAN Guoqing. LPI radar waveform recognition based on deep convolutional neural network transfer learning[J]. *Symmetry*, 2019, 11(4): 540. doi: 10.3390/sym11040540.
- [8] XIAO Yihan, LIU Wenjian, and GAO Lipeng. Radar signal recognition based on transfer learning and feature fusion[J]. *Mobile Networks and Applications*, 2020, 25(4): 1563–1571. doi: 10.1007/s11036-019-01360-1.
- [9] ZHANG Ming, DIAO Ming, GAO Lipeng, *et al.* Neural networks for radar waveform recognition[J]. *Symmetry*, 2017, 9(5): 75. doi: 10.3390/sym9050075.
- [10] QU Zhiyu, MAO Xiaojie, and DENG Zhian. Radar signal intra-pulse modulation recognition based on convolutional neural network[J]. *IEEE Access*, 2018, 6: 43874–43884. doi: 10.1109/access.2018.2864347.
- [11] LIU Yabo and LIU Yi. Modulation recognition with pre-denoising convolutional neural network[J]. *Electronics Letters*, 2020, 56(5): 255–257. doi: 10.1049/el.2019.3586.
- [12] WU Yushuang, LI Xiukun, and WANG Yang. Extraction and classification of acoustic scattering from underwater target based on Wigner-Ville distribution[J]. *Applied Acoustics*, 2018, 138: 52–59. doi: 10.1016/j.apacoust.2018.03.026.
- [13] TIAN Xiaodi, SUN Xiaodong, YU Xiaohui, *et al.* Modulation pattern recognition of communication signals based on fractional low-order Choi-Williams distribution and convolutional neural network in impulsive noise environment[C]. The 19th IEEE International Conference on Communication Technology, Xi'an, China, 2019: 188–192. doi: 10.1109/ICCT46805.2019.8947208.
- [14] ZHANG Kai, ZUO Wangmeng, CHEN Yunjin, *et al.* Beyond a Gaussian denoiser: Residual learning of deep CNN for image denoising[J]. *IEEE Transactions on Image Processing*, 2017, 26(7): 3142–3155. doi: 10.1109/TIP.2017.2662206.
- [15] 邓凌. 基于DnCNN函数的分水岭算法[J]. 海南热带海洋学院学报, 2019, 26(5): 69–75. doi: 10.13307/j.issn.2096-3122.2019.05.12.  
DENG Ling. Watershed algorithm based on DnCNN function[J]. *Journal of Hainan Tropical Ocean University*, 2019, 26(5): 69–75. doi: 10.13307/j.issn.2096-3122.2019.05.12.
- [16] LENZ B, HASSELBRUCH H, GROßMANN H, *et al.* Application of CNN networks for an automatic determination of critical loads in scratch tests on a-C: H: W coatings[J]. *Surface and Coatings Technology*, 2020, 393: 125764. doi: 10.1016/j.surfcoat.2020.125764.
- [17] EMARA T, AFIFY H M, ISMAIL F H, *et al.* A modified inception-v4 for imbalanced skin cancer classification dataset[C]. The 14th International Conference on Computer Engineering and Systems, Cairo, Egypt, 2019: 28–33. doi: 10.1109/ICCES48960.2019.9068110.
- [18] JOSHI K, YADAV R, and ALLWADHI S. PSNR and MSE based investigation of LSB[C]. 2016 International Conference on Computational Techniques in Information and Communication Technologies, New Delhi, India, 2016: 280–285. doi: 10.1109/ICCTICT.2016.7514593.
- 肖易寒: 女, 1980年生, 副教授, 研究方向为雷达信号识别、深度学习、图像处理。  
王亮: 男, 1995年生, 硕士生, 研究方向为雷达信号识别、深度学习。  
郭玉霞: 女, 1979年生, 研究员, 研究方向为雷达导引系统总体设计、信号处理。

责任编辑: 余蓉